

**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU**  
**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I**  
**INFORMACIJSKIH TEHNOLOGIJA OSIJEK**

**Diplomski studij računarstva**

**DCT OPISNIK U ANALIZI 2D OBLIKA**

**Diplomski rad**

**Gabrijela Kramar**

**Osijek, 2018**

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA  
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK**Obrazac D1: Obrazac za imenovanje Povjerenstva za obranu diplomskog rada**

Osijek, 16.09.2018.

**Odboru za završne i diplomske ispite****Imenovanje Povjerenstva za obranu diplomskog rada**

Ime i prezime studenta:	Gabrijela Kramar
Studij, smjer:	Diplomski sveučilišni studij Računarstvo
Mat. br. studenta, godina upisa:	D862R, 27.09.2017.
OIB studenta:	66951002343
Mentor:	Doc.dr.sc. Tomislav Keser
Sumentor:	
Sumentor iz tvrtke:	
Predsjednik Povjerenstva:	Doc.dr.sc. Tomislav Rudec
Član Povjerenstva:	Izv. prof. dr. sc. Alfonso Baumgartner
Naslov diplomskog rada:	DCT opisnik u analizi 2D oblika
Znanstvena grana rada:	<b>Procesno računarstvo (zn. polje računarstvo)</b>
Zadatak diplomskog rada:	Uporaba DCT (directional contour tracing) opisnika u poslovima analize oblika 2D objekata u stacionarnoj slici. Nakon segmentacije 2D oblika provesti DCT analizu te na osnovi rezultata evaluirati uspješnost prepoznavanja i klasifikacije 2D oblika temeljem DCT značajki. Provesti i evaluirati uspješnost primjene DCT metode u poslovima traženja specifičnih značajki na zadanim 2D oblicima.
Prijedlog ocjene pismenog dijela ispita (diplomskog rada):	Izvrstan (5)
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: 3 bod/boda Postignuti rezultati u odnosu na složenost zadatka: 3 bod/boda Jasnoća pismenog izražavanja: 3 bod/boda Razina samostalnosti: 3 razina
Datum prijedloga ocjene mentora:	16.09.2018.
Potpis mentora za predaju konačne verzije rada u Studentsku službu pri završetku studija:	Potpis: Datum:

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA  
I INFORMACIJSKIH TEHNOLOGIJA **OSIJEK****IZJAVA O ORIGINALNOSTI RADA**

Osijek, 30.09.2018.

**Ime i prezime studenta:**

Gabrijela Kramar

**Studij:**

Diplomski sveučilišni studij Računarstvo

**Mat. br. studenta, godina upisa:**

D862R, 27.09.2017.

**Ephorus podudaranje [%]:**

0

Ovom izjavom izjavljujem da je rad pod nazivom: **DCT opisnik u analizi 2D oblika**

izrađen pod vodstvom mentora Doc.dr.sc. Tomislav Keser

i sumentora

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija.  
Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis studenta:

# SADRŽAJ

1. UVOD .....	1
1.1. Zadatak diplomskog rada .....	2
2. DCT OPISNIK I ANALIZA 2D OBLIKA .....	3
2.1. Segmentacija 2D oblika .....	3
2.1.1. Binarizacija slike i HSV prostor boja.....	3
2.1.2. Cannyev detektor rubova .....	3
2.2. DCT opisnik .....	4
2.3. Traženje specifičnih značajki iz DCT opisnika.....	5
2.4. Uspoređivanje DCT opisnika .....	7
3. PRIMJENA DCT ANALIZE I POSTIGNUTI REZULTATI .....	8
3.1. Izvlačenje značajki iz DCT opisnika.....	8
3.2. Klasificiranje prometnih znakova koristeći DCT opisnik.....	22
4. ZAKLJUČAK .....	39
LITERATURA.....	40
SAŽETAK.....	42
ABSTRACT .....	42
ŽIVOTOPIS .....	43
PRILOZI.....	44

## 1. UVOD

Traženje značajki 2D oblika u današnjem životu je vrlo korisno i koristi se u svakom obliku prepoznavanja objekata. Ovaj diplomski rad koncentrira se na izvlačenju i zapisivanju značajki zbog lakšeg analiziranja i prepoznavanja dvodimenzionalnih oblika, a to je sve zasnovano na DCT (engl. *Directional Contour Descriptor*) opisniku. Također, uspoređivanjem DCT opisnika, klasificirati će se prometni znakovi u četiri kategorije: kvadrat, krug, trokut i osmerokut.

Glavni problem prilikom izvlačenja značajki je znati koje značajke su potrebne, koju metodu koristiti i koja je njihova svrha. Izvlačenje značajki moguće je koristiti u razne svrhe kao što su pronalazak i segmentacija prometnih znakova [1], skeniranje rendgenskih slika [2], pronalazak značajki za prepoznavanje lica [3], itd. Metode za prepoznavanje prometnih znakova [1] mogu pronaći sveukupni oblik i prepoznati ga vizualno koristeći metodu sličnoj metodi u radu, no ne mogu izvući značajke kao što su kutovi oblika ili duljina pojedine stranice niti kvantitativno klasificirati prometne znakove. Kod [2] za klasifikaciju slika korišteno je strojno učenje što znači da je za modele potrebno imati uzorak slika za treniranje modela kako bi se uklonile pogreške i izvukle značajke, dok ovdje korištena metoda se oslanja samo na DCT opisniku i njegovoj sposobnosti obilasku konture objekta i izvlačenju seta značajki. U [3] izvlačenje značajki se koristi za procjenu dobi gdje se značajke lica izvlače koristeći različite filtere i zatim se uspoređuju.

Za savladavanje osnova izvlačenja značajki korišten je [4] jer se pokazao kao najbolja osnova za shvaćanje što je izvlačenje značajki. U [5] za izvlačenje značajki koristi se tehnika procjene zavojitosti koja koristi klasifikaciju vrhova točki i algoritma praćenja vršnih linija za razliku od DCT opisnika koji se koristi u ovome radu. Kod [6] koristi se izvlačenje značajki koristeći model kodova boja koji prikazuje da izvlačenje značajki ne mora biti nužno osnovano na geometriji. Različiti pristupi otkrivanja rubova i druge tehnike izvlačenja značajki su prikazane u [7]. Metode korištene tamo su vrlo uspješne, ali vremena obrade bi se mogla poboljšati. Rad [8] koristi CBIR (engl. *Content-Based Image Retrieval*) za izvlačenje značajki kao što su oblici, boja i tekstura te ih koristi za biometrijsku sigurnost. U [9] se za izvlačenje značajki koristi Delaunay-eva triangulacija unutrašnjosti oblika i prikazuje rezultate iste.

Ovaj diplomski rad predstavlja novu metodu izvlačenja značajki, analize dvodimenzionalnih oblika i klasifikacije istih, osnovanu na DCT opisniku za pronalazak stranica i kutova, duljine stranica, stupnjeve kutova, opseg oblika, označavanja značajki na slici te traženja mjere sličnosti za uspoređivanje i klasificiranje oblika.

Rad se dijeli na slijedeća poglavlja: u poglavlju dva dana je teorijska podloga, točnije objašnjavaju se segmentacija 2D oblika koja je korištena u ovom radu, DCT opisnik i kako se dobiva, kako se izvlače značajke iz opisnika te uspoređivanje DCT opisnika; u poglavlju tri dani su eksperimentalni rezultati i pokazana je analiza opisnika danih za reprezentativne oblike i klasifikacija prometnih znakova i na kraju je dan zaključak.

### **1.1. Zadatak diplomskog rada**

Uporaba DCT (engl. *Directional Contour Tracing*) opisnika u poslovima analize oblika 2D objekata u stacionarnoj slici. Nakon segmentacije 2D oblika provesti DCT analizu te na osnovi rezultata evaluirati uspješnost prepoznavanja i klasifikacije 2D oblika temeljem DCT značajki. Provesti i evaluirati uspješnost primjene DCT metode u poslovima traženja specifičnih značajki na zadanim 2D oblicima.

## 2. DCT OPISNIK I ANALIZA 2D OBLIKA

### 2.1. Segmentacija 2D oblika

DCT opisnik dobije se primjenjujući DCT metodu na konturi oblika koji se želi obraditi. Prvo je potrebno izdvojiti oblik iz slike od pozadine, a zatim provesti metodu detekcije rubova da bi se mogla primijeniti DCT metoda.

#### 2.1.1. Binarizacija slike i HSV prostor boja

Postoje razni modeli opisa boja kao što su RGB (engl. *Red, Green, Blue*), HSL (engl. *Hue, Saturation, Lightness*), HSI (engl. *Hue, Saturation and Intensity*), CMYK (engl. *Cyan, Magenta, Yellow, Key/Black*) i sl. RGB prostor boja koristi različite proporcije tri osnovnih boja – crvene, zelene i plave, za prikazivanje svih ostalih boja te time i cijele slike. Svaka od primarnih boja stimulira čunjiće (očne receptore za boju) te one pokrivaju većinu ljudskog spektra boja. Problem kod RGB spektra boja je neosjetljivost na različite nijanse boja. Zato se u ovom radu koristi HSV prostor boja jer je taj prostor boja puno bliži ljudskom načinu gledanja. HSV prostor boja može se promatrati kao valjak koji se sastoji od tri vrijednosti koje određuju boju. Nijansa (engl. *Hue*) je broj koji može biti od 0 do 360 koji predstavlja nijanse crvene, žute, zelene, tirkizne (engl. *cyan*), plave i ružičaste (engl. *magenta*), tj. boje u njihovom najčišćem obliku. Zasićenje (engl. *Saturation*) označava udio sive u slici i može biti od 0% do 100%, dok vrijednost (engl. *Value*) označava svjetlinu boje i također može biti od 0% do 100%, gdje 0% daje crnu boju, a 100% bijelu boju bez obzira na nijansu. Ovisno o razlogu korištenja HSV prostora boja, odgovarajući intervali nijanse, zasićenja i vrijednosti se postavljaju za naglašavanja nekog dijela slike. Ako je piksel unutar zadanih intervala HSV-a, on je bitan i odvaja se od pozadine (označavanjem piksela nekom drugom bojom) te se time napravi binarizacija slike.

#### 2.1.2. Cannyev detektor rubova

Detekcija rubova je jedan od osnovnih alata kod digitalne obrade i analize slike. Osnovna ideja je dobiti informaciju o rubovima nekog objekta na slici na temelju razlikovanja naglih promjena u svjetlini slike. Dobivene informacije mogu se koristiti za izdvajanje objekta iz pozadine, raspoznavanje objekata, kompresiju pozadine i sl.

Cannyev detektor rubova je jedan od najkorištenijih algoritama za detekciju rubova koji je dobio naziv prema Johnu F. Cannyu koji je razvio i prezentirao algoritam 1986. godine. [12]


Cannyev detektor rubova obrađuje ulazno crno-bijelu sliku i vraća izlaznu sliku na kojoj su označeni samo rubovi objekata na slici. Postupak se sastoji od četiri koraka: glaćenje slike (najčešće se koristi Gausov filter 5x5 sa standardnom devijacijom od 1,4), računanje gradijenta intenziteta slike, stanjivanje rubova i usporedba s pragom. [13]

## 2.2. DCT opisnik

DCT (engl. *Directional Contour Tracing*) opisnik je dvodimenzionalni graf koji prikazuje vektor pratećih kutova oblika i dobiven je DCT metodom koja je prezentirana u [10]. Kratak opis metode slijedi. DCT metoda je novija metoda ujedinjenog praćenja i opisa oblika. Ova metoda primjenjuje se na filtriranoj binarnoj slici. Procedura pronalaska DCT opisnika sastoji se od:

- pronalaska rubnih piksela oblika,
- koristeći predefimirani kut pretraživanja,  $\varphi$ , pratiti rubne piksele i zapisati kutove te
- napraviti kumulativno zbrajanje zapisanih kutova.

Za praćenje konture rubova, potrebna su dva parametra: kut smjera traženja prijašnjeg piksela i koordinate idućeg piksela (Sl.2.1.).



a) Traženje piksela u k-tom koraku.      b) Traženje piksela u (k+1)-om koraku.

### Sl.2.1. Primjer DCT metode za dva koraka pretraživanja piksela, preuzeto s [10]

Za pronalazak idućeg piksela računa se matrica  $S(k)$  (2-1), gdje je  $S(k-1)$  kut smjera prijašnjeg piksela i  $D(k)$  matrica predefiniranih i izračunatih smjerova pretraživanja, (2-2).

$$S(k)=S(k-1)+D(k), \quad (2-1)$$

$$D(k) = \begin{bmatrix} \cos(\varphi_{k-1}) & \sin(\varphi_{k-1}) \\ \cos(\varphi_{k-1} + 45^\circ) & \sin(\varphi_{k-1} + 45^\circ) \\ \cos(\varphi_{k-1} - 45^\circ) & \sin(\varphi_{k-1} - 45^\circ) \\ \cos(\varphi_{k-1} + 90^\circ) & \sin(\varphi_{k-1} + 90^\circ) \\ \cos(\varphi_{k-1} - 90^\circ) & \sin(\varphi_{k-1} - 90^\circ) \end{bmatrix} \quad (2-2)$$



Kod pretraživanja idućeg piksela, najpoželjniji smjer za pretraživanje je prvi red matrice  $D(k)$ , nakon njega je drugi, treći, četvrti i peti red, kao što je prikazano u tablici 2.1.

**Tab.2.1.** Prioriteti smjera traženja idućeg piksela

Smjer traženja [rad / °]	Težina pretraživanja [0...4]	Poredak pretraživanja
0 / 0°	0 – Najveća	Prvi
$\pi/4$ / 45°	1 – Veća	Drugi
$-\pi/4$ / -45°	2 – Srednja	Treći
$\pi/2$ / 90°	3 – Manja	Četvrti
$-\pi/2$ / -90°	4 – Najmanja	Peti

Traženje idućeg piksela prestaje kada je nađen prvi pronađeni piksel, ako je prvi pronađeni piksel u blizini ili ako nema niti jednog susjednog piksela. Problem kod ove metode se može pojaviti ako je prekinuta kontura oblika i preporučljivo je koristiti metode koje provjeravaju kontinuitet konture i popunjavaju „rupe“ u konturi ako je potrebno.

### 2.3. Traženje specifičnih značajki iz DCT opisnika

Specifične značajke oblika mogu se izvući na osnovu DCT opisnika. Za razlikovanje stranice od kuta oblika, izračunava se nagib iz dvije točke, gdje prva točka ima koordinate  $(x_1, y_1)$ , a druga  $(x_2, y_2)$ , (2-3).

$$a = \frac{y_2 - y_1}{x_2 - x_1} \quad (2-3)$$

Odabrane točke dio su DCT opisnika, gdje razlika između njih po x osi iznosi 64 (broj je dobiven eksperimentalno i daje najbolje rezultate koji će biti kasnije objašnjeni).

Kada je nagib,  $a$ , manji od 0,06 (koji je također određen eksperimentalno), piksel je dio stranice oblika, a ako je veći ili jednak 0,06, onda je dio kuta, (2-4).

$$a = \begin{cases} < 0.06, & \text{stranica} \\ \geq 0.06, & \text{kut} \end{cases} \quad (2-4)$$

Eksperiment za određivanje razmaka po x osi i nagiba pravca sastojao se od seta slika s različitim specifičnim oblicima (pravokutnik, osmerokut, trokut i krug) gdje su se višestruke razlike između točaka i nagiba testirali kako bi se utvrdile razlike između istih i odabrane vrijednosti su samo one koje uspješno razlikuju stranice od kutova na svakome od oblika k tome da su otporne na šum DCT opisnika. Također je bitno naglasiti da je razlika između točaka uspješna za duljinu konture između 2000 i 4000 piksela jer je razlika između njih samo oko 2% duljine konture. Za manje slike razlika bi trebala biti smanjena, dok bi za još veće trebala biti povećana.

Duljina DCT opisnika označava opseg oblika. Pri određivanju je li piksel dio stranice ili kuta, zapisuju se početna i krajnja točka svake stranice/kuta te su one korištene za računanje duljine stranica i stupnjeve kutova. Duljina stranica računa se prema izrazu (2-5),

$$l_{\text{stranica}} = x_{\text{end}} - x_{\text{start}} \quad (2-5)$$

gdje  $x_{\text{end}}$  predstavlja x koordinatu krajnje točke stranice, a  $x_{\text{start}}$  početnu točku stranice. Važno je naglasiti da zbroj duljina svih stranica ne daje opseg oblika zato što u zbroj nisu uračunate duljine kutova. Za opseg, potrebno je nadodati piksele koji tvore kutove, a nisu klasificirani kao dio stranice.

Stupnjevi kuta u nekom obliku računaju se prema izrazu (2-6) i ovise o tome je li kut oštar, tupi ili izbočeni u nekom obliku.

$$\text{kut} = \begin{cases} 180^\circ - \Delta, & \text{oštar i tupi kut} \\ 180^\circ + \Delta, & \text{izbočeni kut} \end{cases} \quad (2-6)$$

Ovisno o smjeru kretanja DCT opisnika (raste li ili pada), može se uočiti izbočeni kut. Naime, ako DCT opisnik raste s porastom x osi, izbočeni kut će se prikazati kao mali pad grafa. Također vrijedi i obrnuto, ako DCT opisnik opada s porastom x osi, izbočeni kut će rasti na svom dijelu grafa.

$\Delta$  se računa prema izrazu (2-7),

$$\Delta = |y_{\text{end}} - y_{\text{start}}| \quad (2-7)$$

gdje  $y_{\text{end}}$  predstavlja y koordinatu krajnje točke kuta, a  $y_{\text{start}}$  početnu točku kuta. Jedini uvjet kod navedenog izraza je da ako su y koordinate suprotnog predznaka, pozitivna koordinata mora biti na prvom mjestu u spomenutom izrazu (2-7) bez obzira je li ona početna ili krajnja točka kuta.

## 2.4. Uspoređivanje DCT opisnika

Svaki oblik ima jedinstveni DCT opisnik za oblike koje zatim može prepoznati i klasificirati u kategorije.

DCT opisnik ima dvije bitne značajke:

- duljina DCT konture na temelju koje se može zaključiti o veličini oblika i
- oblik krivulje opisnika koja predstavlja specifičan oblik samog oblika.

Dakle, isti oblici različitih veličina imaju različitu duljinu konture, ali isti oblik krivulje opisnika. Za usporedbu dva DCT opisnika koristi se jednostavna razlika između vektora po elementima. Npr. ako postoje dva DCT opisnika A i B, gdje su oni različitih duljina,  $\dim(A) \neq \dim(B)$ , razlika između vektora po elementima ne može se izračunati. Prvo je potrebno napraviti normalizaciju duljina DCT opisnika jednostavnom linearnom interpolacijom na jednak broj elementa vektora,  $L_n$ , pa ih tek onda uspoređivati. Za usporedbu dva DCT opisnika korištena je tehnika razlike klizećih elemenata, (2-8)

$$\delta(k) = A(k) - B|_{k=1}^{L_n} \quad (2-8)$$

gdje  $k$  predstavlja korak u računanju razlike između vektora po elementu, a  $\delta(k)$  je razlika vektora u  $k$ -om koraku.

Nakon svakog koraka razlika devijacije,  $m_{AB}(k)$ , je izračunata prema (2-9) i (2-10),

$$\Delta_{AB}(k) = \delta(k) - \frac{\sum_{i=1}^{L_n} \delta(k)}{L_n}, \quad (2-9)$$

$$m_{AB}(k) = |\max(\Delta_{AB}(k))| - |\min(\Delta_{AB}(k))|, \quad (2-10)$$

gdje  $\Delta_{AB}(k)$  predstavlja devijaciju  $\delta(k)$  i srednju vrijednost  $\delta(k)$  na  $k$ -tom koraku. Devijacija razlike,  $m_{AB}(k)$ , je razlika maksimalne i minimalne devijacije vrijednosti  $\Delta_{AB}(k)$  na  $k$ -tom koraku i nadalje u radu će biti zvana kao *mjera sličnosti*. Mjera sličnosti prikazuje podudaranje ili nepodudaranje dva oblika koji se uspoređuju (2-11).

$$m_{AB}(k) = \begin{cases} \cong 0, & \text{jednaki oblici} \\ > 0, & \text{različiti oblici} \end{cases} \quad (2-11)$$

Dva oblika se podudaraju kada im je mjera sličnosti  $m_{AB}(k)$  najmanja, odnosno približno nuli. Bilo koji  $m_{AB}(k)$  koji je veći od nule prikazuje razliku između dva oblika.

### **3. PRIMJENA DCT ANALIZE I POSTIGNUTI REZULTATI**

Za primjenu DCT analize i izvlačenje značajki oblika, korišteno je MATLAB razvojno okruženje na Windows 10 operacijskom sustavu. Također, za analizu korištene su slike dimenzija 1024x1024px napravljene u GIMP-u (engl. *GNU Image Manipulation Program*) i fotografije.

DCT opisnik u analizi 2D oblika moguće je iskoristiti za više različitih primjena. U ovom radu su prikazana dva specifična slučaja za korištenje DCT opisnika:


- izvlačenje značajki i
- klasifikacija prometnih znakova.

Kod izvlačenja značajki, DCT opisnik koristi se za pronalaženje kutova i stranica oblika te odgovarajućih duljina i veličina. Nakon što su kutovi i stranice pronađeni, označavaju se na slici. Također, mjeri se vrijeme performansi rada DCT opisnika (duljina izračuna) i potrebno vrijeme za izvlačenje značajki.

Kod klasifikacije prometnih znakova, analiza se provodi na nekoliko specifičnih oblika: kvadrat (znakovi obavijesti), trokut (znakovi opasnosti), krug (znakovi izričitih naredbi) i osmerokut (znak obaveznog zaustavljanja). Znakove je prvo potrebno izvući iz okoline, zatim izračunati DCT opisnik kako bi se pronašao oblik i na kraju koristiti mjeru sličnosti kako bi se klasificirao prometni znak.

#### **3.1. Izvlačenje značajki iz DCT opisnika**

Na slici 3.1. predstavljena je primjena DCT opisnika na paralelogramu.



**Slika 3.1.** DCT opisnik za paralelogram s označenim početkom i krajem kutova

Moguće je vidjeti četiri karakteristične stepenice koje predstavljaju kutove i stranice paralelograma (četverokuta). Metoda uspješno pronalazi četiri kuta u paralelogramu, njihove početne i krajnje točke te četiri stranice paralelograma s njihovim početnim i krajnjim točkama kao što je vidljivo i u tablicama 3.1. i 3.2.

**Tab.3.1.** Specifikacije pronađenih stranica paralelograma

	<b>x<sub>start</sub> piksel</b>	<b>x<sub>end</sub> piksel</b>	<b>Duljina stranice [px]</b>
<b>Stranica 1</b>	1	481	480
<b>Stranica 2</b>	662	1383	721
<b>Stranica 3</b>	1565	2050	485
<b>Stranica 4</b>	2231	2952	721


**Tab.3.2.** Specifikacije pronađenih kutova paralelograma

	<b>x<sub>start</sub> piksel</b>	<b>x<sub>end</sub> piksel</b>	<b>Stupnjevi pronađenog kuta [°]</b>
<b>Kut 1</b>	481	662	98.789
<b>Kut 2</b>	1383	1565	87.539
<b>Kut 3</b>	2050	2231	98.789
<b>Kut 4</b>	2952	3138	84.727

U obje tablice dane su koordinate apscise za početak i kraj stranice, odnosno kuta. U tablici 3.1. izračunate su duljine stranica i iz rezultata je moguće primijetiti da su parovi stranica vrlo slični, što odgovara stranicama paralelograma koji dvije nasuprotne stranice jednakih duljina. Također,


može se primijetiti u tablici 3.2. pravilnost kod kutova gdje su opet parovi vrlo sličnih vrijednosti. Razlike između kutova i stranica se događaju zbog pogreške i nesavršenosti metode. Vrijeme izračuna DCT opisnika za ovaj oblik je  $t = 1.2953s$ , a potrebno vrijeme za izvlačenje značajki je  $t = 0.0084764s$ .

Pronađene kutove i stranice je također moguće označiti na obliku, što je i napravljeno na slici 3.3. gdje su kutovi označeni narančastom, a stranice crnom bojom.



**Slika 3.2.** Paralelogram s označenim kutovima i stranicama

Slika 3.3. prikazuje DCT opisnik za jednakokračni trokut.



**Slika 3.3.** Jednakokračan s označenim kutovima i stranicama

Kod DCT opisnika trokuta, moguće je vidjeti tri karakteristične stepenice koje predstavljaju tri kuta/stranice trokuta. Metoda uspješno pronalazi sve kutove i stranice trokuta, te njihove početne

i krajnje točke. Tablica 3.3. prikazuje početne i krajnje točke stranica, dok tablica 3.4. prikazuje kutove trokuta i njihove vrijednosti.

**Tab.3.3.** Specifikacije pronađenih stranica trokuta


	<b>x<sub>start</sub> piksel</b>	<b>x<sub>end</sub> piksel</b>	<b>Duljina stranice [px]</b>
<b>Stranica 1</b>	1	579	578
<b>Stranica 2</b>	763	1346	583
<b>Stranica 3</b>	1529	2111	582

**Tab.3.4.** Specifikacije pronađenih kutova trokuta

	<b>x<sub>start</sub> piksel</b>	<b>x<sub>end</sub> piksel</b>	<b>Stupnjevi pronađenog kuta [°]</b>
<b>Kut 1</b>	579	763	71.016
<b>Kut 2</b>	1346	1529	71.016
<b>Kut 3</b>	2111	2300	45.352


U obje tablice dane su koordinate apscise za početak i kraj stranice, odnosno kuta. U tablici 3.3. izračunate su duljine stranica i iz rezultata je moguće primijetiti da su parovi stranica vrlo slični, a treća stranica ima malo drugačije dimenzije od ostale dvije. Ovo odgovara stranicama jednakokraknog trokuta koji ima dva kraka (stranice) iste duljine i jednu stranicu različite duljine od ostalih. Ovo se također može vidjeti u tablici 3.4. kod kutova, gdje je par kutova isti i treći kut koji je drugačiji, što specificira jednakokrakni trokut. Vrijeme izračuna DCT opisnika za ovaj oblik je  $t = 1.7545s$ , a potrebno vrijeme za izvlačenje značajki je  $t = 0.0074536s$ .

Pronađene kutove i stranice moguće je označiti, što je i napravljeno na slici 3.4. gdje su kutovi označeni narančastom, a stranice crnom bojom.



**Slika 3.4.** Jednakokračan trokut s označenim kutovima i stranicama

Slika 3.5. prikazuje DCT opisnik za šesterokutni oblik.



**Slika 3.5.** DCT opisnik za šesterokutni oblik s izbočenim kutovima

Na slici 3.5 moguće je vidjeti šest različitih kutova i stranica koje označavaju ovaj oblik. Međutim za razliku od ostalih do sada prikazanih oblika, ovaj oblik ima specifične rastuće stepenice koje predstavljaju izbočene kutove na ovome obliku (postoje dva takva kuta). Metoda uspješno pronalazi sve kutove i stranice šesterokutnog oblika, te njihove početne i krajnje točke. Tablice 3.5 i 3.6. prikazuju početne i krajnje točke stranica, odnosno kutova šesterokutnog oblika i njihove vrijednosti.



**Tab.3.5.** Specifikacije pronađenih stranica šesterokutnog oblika


	<b>x<sub>start</sub> piksel</b>	<b>x<sub>end</sub> piksel</b>	<b>Duljina stranice [px]</b>
<b>Stranica 1</b>	1	103	102
<b>Stranica 2</b>	214	323	109
<b>Stranica 3</b>	505	1239	734
<b>Stranica 4</b>	1422	1529	107
<b>Stranica 5</b>	1640	1747	107
<b>Stranica 6</b>	1929	2662	733

**Tab.3.6.** Specifikacije pronađenih kutova šesterokutnog oblika

	<b>x<sub>start</sub> piksel</b>	<b>x<sub>end</sub> piksel</b>	<b>Stupnjevi pronađenog kuta [°]</b>
<b>Kut 1</b>	103	214	188.09
<b>Kut 2</b>	323	505	93.164
<b>Kut 3</b>	1239	1422	81.211
<b>Kut 4</b>	1529	1640	188.09
<b>Kut 5</b>	1747	1929	93.164
<b>Kut 6</b>	2662	2847	79.805


U obje tablice dane su x koordinate za početak i kraj stranice, odnosno kuta. U tablici 3.5. izračunate su duljine stranica i iz rezultata je moguće uočiti da par stranica („Stranica 3“ i „Stranica 6“) su otprilike iste duljine i to su najdulje stranice tijela, te da su preostale četiri stranice otprilike iste duljine (zbog pogreške nisu u potpunosti iste duljine). Ovo odgovara stranicama prikazanog oblika koji ima dvije stranice duže od ostalih i četiri približno iste stranice. U tablici 3.6. primjećuje se da su „Kut 1“ i „Kut 4“ veći od 180° što ih čini izbočenim. Također, parovi kutova na objektu su „Kut 2“ i „Kut 5“ koji imaju iste stupnjeve kuta te „Kut 3“ i „Kut 6“ koji su jako slični. Vrijeme izračuna DCT opisnika za ovaj oblik iznosi  $t = 1.0523s$ , a potrebno vrijeme za izvlačenje značajki iznosi  $t = 0.0073221s$ .

Pronađene kutove i stranice je također moguće označiti, što je i napravljeno na slici 3.6. gdje su kutovi označeni narančastom, a stranice crnom bojom.



**Slika 3.6.** Šesterokutni oblik s označenim kutovima i stranicama

Slika 3.7. prikazuje DCT opisnik za osmerokut.



**Slika 3.7.** DCT opisnik za osmerokut

Kod DCT opisnika moguće je vidjeti osam karakterističnih stepenica koje označavaju osmerokut. Metoda uspješno pronalazi sve kutove i stranice osmerokuta, te njihove početne i krajnje točke. Tablice 3.7 i 3.8. prikazuju početne i krajnje točke stranica, odnosno kutova šesterokutnog oblika i njihove duljine/stupnjeve.

**Tab.3.7.** Specifikacije pronađenih stranica osmerokuta


	<b>x<sub>start</sub> piksel</b>	<b>x<sub>end</sub> piksel</b>	<b>Duljina stranice [px]</b>
<b>Stranica 1</b>	1	66	65
<b>Stranica 2</b>	197	452	255
<b>Stranica 3</b>	623	688	65
<b>Stranica 4</b>	843	1121	278
<b>Stranica 5</b>	1292	1357	65
<b>Stranica 6</b>	1486	1738	252
<b>Stranica 7</b>	1905	1973	68
<b>Stranica 8</b>	2147	2410	263

**Tab.3.8.** Specifikacije pronađenih kutova osmerokuta

	<b>x<sub>start</sub> piksel</b>	<b>x<sub>end</sub> piksel</b>	<b>Stupnjevi pronađenog kuta [°]</b>
<b>Kut 1</b>	66	197	138.52
<b>Kut 2</b>	452	623	138.52
<b>Kut 3</b>	688	843	138.52
<b>Kut 4</b>	1121	1292	138.52
<b>Kut 5</b>	1357	1486	138.52
<b>Kut 6</b>	1738	1905	142.03
<b>Kut 7</b>	1973	2147	134.65
<b>Kut 8</b>	2410	2592	135


U obje tablice dane su koordinate apscise za početak i kraj stranice, odnosno kuta. U tablici 3.7. izračunate su duljine stranica i iz rezultata može se uočiti da su četiri od 8 stranica jednake („Stranica 1“, „Stranica 3“, „Stranica 5“ i „Stranica 7“) i to su najkraće stranice osmerokuta, a preostale četiri stranice su također slične duljine (zbog pogreške nisu u potpunosti iste duljine). Ovo odgovara stranicama prikazanog oblika koji ima četiri kraće i četiri duže stranice. U tablici 3.8. se može primijetiti da su svi kutovi skoro pa jednaki no značajnija razlika između veličine kutova se najbolje očituje na kutovima 6, 7 i 8. Ovo se događa zbog pogreške u algoritmu i nepravilnosti napravljenog osmerokuta. Vrijeme izračuna DCT opisnika za ovaj oblik je  $t = 1.6759s$ , a potrebno vrijeme za izvlačenje značajki je  $t = 0.0075346s$ .

Pronađeni kutovi i stranice označeni su na slici 3.8, gdje su kutovi označeni narančastom, a stranice crnom bojom.



**Slika 3.8.** Osmerokut s označenim kutovima i stranicama

Slika 3.9. prikazuje DCT opisnik za zvijezdu s šest krakova.



**Slika 3.9.** DCT opisnik za zvijezdu s šest krakova

Na DCT opisniku primjećuje se 12 različitih karakterističnih kutova i stranica koje označavaju ovaj oblik. Metoda uspješno pronalazi sve kutove i stranice zvijezde s šest krakova, te njihove početne i krajnje točke. Tablice 3.9 i 3.10. prikazuju početne i krajnje točke stranica, odnosno kutova zvijezde s šest krakova i njihove vrijednosti.

**Tab.3.9.** Specifikacije pronađenih stranica zvijezde s šest krakova

	<b>x<sub>start</sub> piksel</b>	<b>x<sub>end</sub> piksel</b>	<b>Duljina stranice [px]</b>
<b>Stranica 1</b>	1	66	65
<b>Stranica 2</b>	227	348	121
<b>Stranica 3</b>	533	598	65
<b>Stranica 4</b>	764	829	65
<b>Stranica 5</b>	1004	1125	121
<b>Stranica 6</b>	1300	1365	65
<b>Stranica 7</b>	1542	1607	65
<b>Stranica 8</b>	1773	1895	122
<b>Stranica 9</b>	2079	2144	65
<b>Stranica 10</b>	2310	2375	65
<b>Stranica 11</b>	2551	2673	122
<b>Stranica 12</b>	2848	2913	65


**Tab.3.10.** Specifikacije pronađenih kutova zvijezde s šest krakova

	<b>x<sub>start</sub> piksel</b>	<b>x<sub>end</sub> piksel</b>	<b>Stupnjevi pronađenog kuta [°]</b>
<b>Kut 1</b>	66	227	125.86
<b>Kut 2</b>	348	533	63.984
<b>Kut 3</b>	598	764	125.51
<b>Kut 4</b>	829	1004	63.984
<b>Kut 5</b>	1125	1300	125.86
<b>Kut 6</b>	1365	1542	67.5
<b>Kut 7</b>	1607	1773	125.86
<b>Kut 8</b>	1895	2079	64.688
<b>Kut 9</b>	2144	2310	126.21
<b>Kut 10</b>	2375	2551	63.984
<b>Kut 11</b>	2673	2848	125.86
<b>Kut 12</b>	2913	3093	65.039

U obje tablice su dane koordinate apscise za početak i kraj stranice, odnosno kuta. U tablici 3.9. prikazane su duljine stranica i iz rezultata je moguće primijetiti da su četiri od 12 stranica jednake („Stranica 2“, „Stranica 5“, „Stranica 8“ i „Stranica 11“) i to su najdulje stranice zvijezde s šest


krakova, a preostalih osam stranica su međusobno iste duljine (kraće stranice zvijezde). U tablici 3.10. kutovi se izmjenjuju između oštrog i tupog kuta što dogovara obliku zvijezde. Vrijeme izračuna DCT opisnika za ovaj oblik iznosi  $t = 1.8201s$ , a potrebno vrijeme za izvlačenje značajki je  $t = 0.0077894s$ .

Pronađene kutove i stranice je također moguće označiti, što je i napravljeno na slici 3.10. gdje su kutovi označeni narančastom, a stranice crnom bojom.




**Slika 3.10.** Zvijezda s šest krakova i označenim stranicama i kutovima

Na slici 3.11. prikazan je realni scenarij za gdje se izvlači ploča za pisanje kao najveći objekt na slici i njegov DCT opisnik je prikazan na slici 3.12.



**Slika 3.11.** Stvarni scenarij za izvlačenje objekata – ploča za pisanje



**Slika 3.12.** DCT opisnik ploče za pisanje

Za izvlačenje ploče za pisanje potrebno je prvo izdvojiti objekt od pozadine, a za to je korišten pristup kromatskog odvajanja gdje se postavljaju intervali HSV-a za izdvajanje svijetlo plave boje iz pozadine. Trenutna metoda je pronašla četiri kuta i četiri stranice koje odgovaraju fotografiranome objektu – pravokutnoj ploči za pisanje. U tablici 3.11. prikazane su specifikacije pronađenih stranica.

**Tab. 3.11.** Specifikacije pronađenih stranica ploče za pisanje

	<b>x<sub>start</sub> piksel</b>	<b>x<sub>end</sub> piksel</b>	<b>Duljina stranice [px]</b>
<b>Stranica 1</b>	1	96	95
<b>Stranica 2</b>	277	434	157
<b>Stranica 3</b>	617	910	293
<b>Stranica 4</b>	1091	1243	152
<b>Stranica 5</b>	1425	1602	177

U tablici 3.11. prikazane su početne i krajnje točke osi apscise te duljine stranica u pikselima. Vrlo je bitno naglasiti da zbrajanjem „Stranice 1“ i „Stranice 5“ dobije se duljina jedne stranice. Navedene stranice su razdvojene zato što DCT opisnik počinje od trećine stranice pravokutnika (tamo je nađen prvi piksel) čime je jedna njegova stranica podijeljena na dva dijela. Metoda je pronašla 2 para stranica podjednake duljine (razlike se događaju zbog šuma na slici) koji potvrđuju


da je oblik objekta četverokut. U tablici 3.12. prikazane su specifikacije pronađenih kutova ploče za pisanje.

**Tab. 3.12.** Specifikacije pronađenih kutova ploče za pisanje

	<b><math>x_{\text{start}}</math> piksel</b>	<b><math>x_{\text{end}}</math> piksel</b>	<b>Stupnjevi pronađenog kuta [°]</b>
<b>Stranica 1</b>	96	277	94.57
<b>Stranica 2</b>	434	617	91.055
<b>Stranica 3</b>	910	1091	92.461
<b>Stranica 4</b>	1243	1425	94.57

Zbog šumova i kuta fotografiranja kutovi prikazani u tablici 3.12. nisu točno  $90^\circ$  već ulaze u dozvoljenu pogrešku metode, ali su još uvijek karakteristični za četverokut. Vrijeme izračuna DCT opisnika za ovaj oblik je  $t = 0.17809s$ , a potrebno vrijeme za izvlačenje značajki je  $t = 0.022944$ .

Cijeli proces pronalaska DCT opisnika napravljen je na vanjskom obrubu četverokuta i na slici 3.13. prikazan je objekt s označenim kutovima i stranicama.




**Slika 3.13.** Ploča za pisanje s označenim kutovima i stranicama

Na slici 3.14. nalazi se još jedan stvarni scenarij za izvlačenje okruglog poklopca, dok je na slici 3.15. prikazan DCT opisnik objekta sa slike.





**Slika 3.14.** Stvarni scenarij za izvlačenje objekta – okrugli poklopac



**Slika 3.15.** DCT opisnik okruglog poklopca

Ovdje je bitno naglasiti da je kontura skoro pa ravna kao pravac, te nema karakterističnih stepenica koji označavaju kutove i stranice. To znači da ovaj oblik ima stalnu promjenu kuta, a s obzirom da je DCT opisnik moguće upotrijebiti samo na zatvorenoj konturi, objekt kružnog oblika. Može se reći da se krug i kružni oblici sastoje samo od „jednog kuta“ koji ne prestaje što se može vidjeti na slici 3.16. gdje je taj „kut“ i obojan.



**Slika 3.16.** Okrugli poklopac s označenim „kutovima“ i „stranicama“

### **3.2. Klasificiranje prometnih znakova koristeći DCT opisnik**

Testiranje se izvodi na trokutastim, okruglim, kvadratnim/pravokutnim i osmerokutnim prometnim znakovima. Napravljeni su na nekoliko različitih konfiguracija za svaki pojedini znak. Konfiguracije uključuju fotografirane prometne znakove u stvarnim situacijama na različitim udaljenostima i projekcijama (distorzija znaka ovisno o blizini u prostoru). DCT opisnik biti će analiziran i uspoređivan ovisno o obliku i distorziji prometnog znaka. Vremena računanja ovise o različitim platformama i mogu se značajno razlikovati na drugačijim konfiguracijama.

Na slikama 3.17 do 3.19 nalaze se fotografije analiziranog prometnog znaka izričite naredbe (znak dopuštenih smjerova) iz različitih perspektiva i kutova gledanja. Pripadajući DCT opisnici nalaze se na slikama 3.20 do 3.22.




**Slika 3.17.** Znak dopuštenih smjerova fotografiran iz blizine




**Slika 3.18.** Znak dopuštenih smjerova fotografiran iz daljine




**Slika 3.19.** Distorziran znak dopuštenih smjerova



**Slika 3.20.** DCT opisnik znaka fotografiranog iz blizine



**Slika 3.21.** DCT opisnik znaka fotografiranog iz daljine



**Slika 3.22.** DCT opisnik distorziranog znaka

DCT opisnici prikazani na slikama 3.20. do 3.22. predstavljaju znak izričite naredbe (dopušteni smjerovi) koji je kružnog oblika. Na njemu je vidljivo da neovisno o udaljenosti fotografiranja prometnog znaka ili distorziji zbog kuta gledanja, duljine konture svih situacija su jednake. Razlog tome je zbog korištenja normalizacije radi korištenja mjere sličnosti i uspoređivanja znaka s poznatim oblicima kako bi se klasificirao oblik istog. Na slikama se može vidjeti da opisnik nije u potpunosti gladak, a to je rezultat šuma na slici i nesavršene kromatske separacije slike, no specifičnost kružnog oblika gdje se konstantno mijenja kut relativne putanje piksela je i dalje vidljiv. Rast ili pad DCT opisnika ovisi o tome u kojem je smjeru običen traženi oblik. Pri uspoređivanju DCT opisnika nađenog i referentnog oblika, smjer kretanja DCT opisnika se ujednače (ako jedan DCT opisnik raste, onda će i referentni rasti te obrnuto). Tablica 3.13. predstavlja rezultate analize znaka dopuštenih smjerova.

**Tab. 3.13.** Analiza i rezultati uspoređivanja znaka dopuštenih smjerova

Oblik	Mjera sličnosti, $m_{AB}$		
	Blizu	Daleko	Distorzija
<b>Krug</b>	4.8286	2.6921	90.413
<b>Kvadrat</b>	19.657	18.746	90.222
<b>Trokut</b>	27.362	29.195	78.203
<b>Osmerokut</b>	10.973	9.9011	90.041

Prema tablici 3.13. znak se klasificira kao krug zbog njegove mjere sličnosti koja za znak koji je fotografiran iz blizine i daljine je najmanji od svih ostalih uspoređivanih oblika. Distorzirani znak nije prepoznat kao jedan od uspoređivanih oblika, a razlog tome je zato što se distorzijom kruga dobiva eliptični oblik. Eliptični oblici imaju svoj specifični DCT opisnik koji je jako sličan kao kod kruga, ali je ipak drugačiji i ne može se klasificirati kao krug. Također je bitno za naglasiti da se traženi prometni znak ne klasificira kao osmerokut, što kod nekih metoda zna biti problem.

Vrijeme izračuna DCT opisnika za svaku od ovih pojedinih fotografija je drugačiji zbog različitih veličina objekata na fotografiji. Vrijeme za opisnik na slici 3.20. iznosi  $t=3.921s$ , za opisnik na slici 3.21. iznosi  $t=2.535s$  i za opisnik na slici 3.22. iznosi  $t=4.872s$ . Što je veći objekt na slici to više vremena treba da se izračuna DCT opisnik kao što je to slučaj u ovome primjeru s znakom fotografiranim iz blizine i distorziranim oblikom.

Na slikama 3.23 do 3.25 nalaze se fotografije analiziranog prometnog znaka obavijesti (slijepa ulica) iz različitih perspektiva i kutova gledanja. Njegovi DCT opisnici nalaze se na slikama 3.26 do 3.28.



**Slika 3.23.** Znak slijepe ulice fotografiran iz blizine




**Slika 3.24.** Znak slijepe ulice fotografiran iz daljine






**Slika 3.25.** Distorzirani znak slijepe ulice




**Slika 3.26.** DCT opisnik znaka slijepe ulice fotografiranog iz blizine





**Slika 3.27.** DCT opisnik znaka slijepe ulice fotografiranog iz daljine



**Slika 3.28.** DCT opisnik distorziranog znaka slijepe ulice

Na slikama 3.26. do 3.28. prikazani su DCT opisnici znaka obavijesti (slijepa ulica) koji je pravokutnog, odnosno kvadratnog oblika. Prema slici, sva tri DCT opisnika imaju karakteristične četiri „stepenice“ koje karakteriziraju četiri strane/kuta kvadratnog oblika. Kao rezultat korištenja normalizacije, duljina konture pojedinog opisnika za različite slučajeve spomenutog znaka je jednaka za svaku fotografiju (iznosi 2048 piksela) kako bi se DCT opisnici mogli uspoređivati s referentnim oblikom i računati mjera sličnosti. Tablica 3.14. predstavlja rezultate analize s mjerom sličnosti za sve situacije na slikama 3.26. do 3.28.

**Tab. 3.14.** Analiza i rezultati uspoređivanja znaka slijepe ulice

Oblik	Mjera sličnosti, $m_{AB}$		
	Blizu	Daleko	Distorzija
<b>Krug</b>	17.351	14.988	23.708
<b>Kvadrat</b>	2.0844	4.2902	19.45
<b>Trokut</b>	31.422	31.416	23.768
<b>Osmerokut</b>	18.152	15.934	24.009

U tablici 3.14. prikazane su mjere sličnosti analiziranog znaka kvadratnog oblika. Analizom mjera sličnosti moguće je vidjeti da za sve tri kategorije može se reći da je znak kvadrat. Ovo je najbolje moguće vidjeti kod fotografije iz blizine gdje postoji najmanje šuma analiziranog objekta jer je objekt zauzimao najveći dio fotografije. Distorzirani znak ima najslabije rezultate i mnogo veću mjeru sličnosti, nego kada je znak fotografiran iz blizine i daljine, te gledajući mjeru sličnosti se ne može klasificirati kao kvadrat (jer nije približno 0), no još uvijek se može prepoznati da se prometni znak treba svrstati u klasu kvadrata/pravokutnika jer je mjera sličnosti s uspoređivanim kvadratom manja, nego s ostalim uspoređivanim oblicima. Uz posebne uvjete klasificiranja prometnih znakova, znak slijepe ulice moguće je klasificirati kao kvadrat.

Vremena izračuna DCT opisnika za svaku pojedinu fotografiju je drugačiji i ovisni o udaljenosti od samog objekta (što je bliže objekt na fotografiji to je i veći sam objekt). Vrijeme za opisnik na slici 3.26. iznosi  $t=1.9115s$ , za opisnik na slici 3.27. iznosi  $t=1.8489s$  i za opisnik na slici 3.28. iznosi  $t=2.572s$ . U ovom slučaju najveće vrijeme izračuna DCT opisnika je za distorzirani objekt jer je on ujedno i najveći objekt od sva tri analizirana na ovim fotografijama.

Na slikama 3.29. do 3.31. nalaze se fotografije znaka obaveznog zaustavljanja iz različitih perspektiva i kutova gledanja. DCT opisnici za analizirani znak se nalaze na slikama 3.32. do 3.34.




**Slika 3.29.** Znak obaveznog zaustavljanja fotografiran iz blizine




**Slika 3.30.** Znak obaveznog zaustavljanja fotografiran iz daljine




**Slika 3.31.** Distorzirani znak obaveznog zaustavljanja



**Slika 3.32.** DCT opisnik znaka obaveznog zaustavljanja fotografiranog iz blizine



**Slika 3.33.** DCT opisnik znaka obaveznog zaustavljanja fotografiranog iz daljine



**Slika 3.34.** DCT opisnik distorziranog znaka obaveznog zaustavljanja

Slike 3.29. do 3.31. prikazuju DCT opisnike znaka obaveznog zaustavljanja koji je osmerokutnog oblika. Svaki DCT opisnik je normaliziran na duljinu od 2048 piksela zbog uspoređivanja i računanja mjere sličnosti. Na slikama se može vidjeti da stepenice opisnika nisu u potpunosti ravne zbog raznih šumova na slici, no vidljivo je osam karakterističnih stepenica koje označavaju osam stranica/kutova osmerokuta. Tablica 3.15. predstavlja rezultate analize znaka obaveznog zaustavljanja s mjerom sličnosti za sve prikazane situacije.

**Tab. 3.15.** Analiza i rezultati uspoređivanja znaka obaveznog zaustavljanja

Oblik	Mjera sličnosti, $m_{AB}$		
	Blizu	Daleko	Distorzija
<b>Krug</b>	10.427	7.4437	13.658
<b>Kvadrat</b>	18.943	18.625	21.337
<b>Trokut</b>	29.737	29.302	28.491
<b>Osmerokut</b>	0.95589	3.8442	12.173

U tablici 3.15. moguće je vidjeti mjere sličnosti analiziranog osmerokutnog znaka kada je fotografiran iz blizine, daljine i kada je dobivena prostorna distorzija prilikom fotografiranja. Najbolji rezultati za ovaj znak dobiveni su kada je napravljena fotografija iz neposredne blizine te je tada mjera sličnosti približno nula što potvrđuje da je objekt osmerokut. Udaljavanjem od znaka, mjera sličnosti raste, ali ne toliko značajno da nije moguće u potpunosti prepoznati znak da je još uvijek osmerokutnog oblika. Kod analizirane distorzije, mjera sličnosti je značajnije narasla te detaljnijom analizom može se vidjeti da je vrlo blizu krugu. Gledajući mjeru sličnosti, distorzirani oblik ne može se klasificirati kao osmerokut (jer nije približno 0), no još uvijek se može primjetiti da se prometni znak treba svrstati u klasu osmerokuta jer je mjera sličnosti s referentnim osmerokutom manja nego s ostalim uspoređivanim oblicima. Također, bitno je naglasiti kako se analizom DCT opisnika mogu razlikovati krug i osmerokut. Uz posebne uvjete klasificiranja prometnih znakova, znak obaveznog zaustavljanja moguće je klasificirati kao osmerokut.

Vrijeme izračuna DCT opisnika za svaku pojedinu fotografiju je drugačije. Ono ovisi o veličini objekta koja izravno ovisi o blizini fotografiranog objekta. Vrijeme za opisnik na slici 3.32. iznosi  $t=3.507s$ , za opisnik na slici 3.33. iznosi  $t=2.6254s$  i za opisnik na slici 3.34. iznosi  $t=2.8594s$ . Najveće vrijeme izračuna DCT opisnika u ovome slučaju je za stop znak slikan iz blizine jer je tada objekt najveći.

Na slikama 3.35. do 3.37. nalaze se fotografije analiziranog znaka opasnosti (zavoj udesno) iz različitih perspektiva i kutova gledanja. Njegovi DCT opisnici nalaze se na slikama 3.38. do 3.40.



**Slika 3.35.** Znak „zavoj ulijevo“ fotografiran iz blizine






**Slika 3.36.** Znak „zavoj ulijevo“ fotografiran iz daljine




**Slika 3.37.** Distorzirani znak „zavoj ulijevo“






**Slika 3.38.** DCT opisnik za znak „zavoj ulijevo“ fotografiranog iz blizine



**Slika 3.39.** DCT opisnik za znak „zavoj ulijevo“ fotografiranog iz daljine



**Slika 3.40.** DCT opisnik distorziranog znaka „zavoj ulijevo“

DCT opisnici znaka opasnosti („zavoj ulijevo“) nalaze se na slikama 3.38. do 3.40. te prema obliku opisnika i broju stepenica moguće je zaključiti da predstavljaju trokutasti oblik. U tablici 3.16 prikazani su rezultati analize znaka „zavoj ulijevo“ s mjerom sličnosti za sve predstavljene situacije.

**Tab. 3.15.** Analiza i rezultati uspoređivanja znaka „zavoj ulijevo“

Oblik	Mjera sličnosti, $m_{AB}$		
	Blizu	Daleko	Distorzija
<b>Krug</b>	28.289	26.957	28.188
<b>Kvadrat</b>	31.806	30.954	31.759
<b>Trokut</b>	7.4129	6.2686	4.8364
<b>Osmerokut</b>	28.896	27.452	28.311

Tablica 3.15. prikazuje mjere sličnosti analiziranog trokutastog znaka u sva tri slučaja s četiri osnovna oblika. Mjere sličnosti za svaku situaciju ukazuju na to da je analizirani objekt trokut. Najmanja mjera sličnosti i time najbliža analizirana fotografija referentnom obliku u ovome slučaju je distorzirana fotografija. Ovo se događa jer prilikom uvođenja distorzije trokut nije značajno promijenjen od početnog oblika te je zbog boljih svjetlosnih uvjeta na slici, crvena boja trokuta jasnije i lakše izvučena. Na temelju prikazanih rezultata moguće je klasificirati analizirani znak „zavoj ulijevo“ kao trokut.

DCT opisnik za svaku pojedinu fotografiju analiziranog znaka za zavoj udesno ima različita vremena izračuna ovisno o udaljenosti od znaka i kutu gledanja (distorziji). Vrijeme za opisnik na slici 3.38. iznosi  $t=3.52s$ , za opisnik na slici 3.39. iznosi  $t=2.1433s$  i za opisnik na slici 3.40. iznosi  $t=4.883s$ . Najveće vrijeme izračuna DCT opisnika ima objekt na kojemu je oblik distorziran jer je to ujedno i najveći objekt na svim fotografijama za taj znak. Najmanje vrijeme kao i kod svakoga do sada analiziranog znaka ima objekt fotografiran iz daljine jer se fotografiranjem iz daljine dobiva najmanji objekt od svih analiziranih fotografija za pojedini znak.

## 4. ZAKLJUČAK

Za analizu oblika u današnje vrijeme postoji mnogo različitih metoda koje se mogu upotrijebiti u različitim poljima znanosti, a ne samo u računalnim granama znanosti. DCT opisnik u analizi 2D oblika može pronaći veliku primjenu u praksi za izvlačenje značajki i prepoznavanje oblika. Opisana metoda izvedena je u nekoliko koraka. Prvo je pronalazak ruba traženog objekta (pronazak konture) pomoću Canny metode, zatim se provodi DCT metoda za pronalazak DCT opisnika, nakon čega se izvlače značajke oblika kao što su kutovi i stranice objekta te se na temelju njih zaključuje o obliku analiziranog objekta. Metoda opisana u ovom radu računa stupnjeve kutova i duljine stranica te njihove početne i krajnje točke na DCT opisniku i analiziranom obliku. Na kraju se označavaju svi pronađeni kutovi i stranice na slici za lakši i bolji vizualni prikaz istih. Metoda uspješno pronalazi sve vrste kutova (oštri, tupi ili izbočeni) i duljine stranica, gdje su kutovi izraženi u stupnjevima, a duljine stranice u pikselima.

Osim izvlačenja značajki u ovome radu napravljena je klasifikacija prometnih znakova ovisno o njihovom obliku. Kako bi se znakovi mogli klasificirati potrebno je napraviti uspoređivanje DCT opisnika s DCT opisnikom nekog referentnog oblika (za prometne znakove to su kvadrat, krug, trokut i osmerokut). Za uspoređivanje DCT opisnika koristi se mjera sličnosti koja služi za prikazivanje podudaranja dva uspoređivana oblika. Ako je mjera sličnosti približna nuli onda su to jednaki oblici, inače su ti oblici različiti. Kod analize prometnih znakova, promatrana su tri različita scenarija prometnih znakova, znak iz blizine, znak iz daljine i distorzirani znak. Rezultati su pokazali da se prometni znakovi mogu klasificirati koristeći DCT opisnik i mjeru sličnosti, no kod distorziranih znakova primijećena je osjetljivost DCT opisnika gdje je samo trokutasti oblik otporan na distorziju. No, promatrajući mjere sličnosti između referentnih oblika i analiziranog prometnog znaka, oblik koji ima prometni znak ima najmanju mjeru sličnosti s referentnim oblikom.

Računanje DCT opisnika relativno je jednostavno jer nema kompleksne izračune i to ga čini vrlo dobrim za izvlačenje značajki na bilo kojoj platformi, no uvjet za uspješnu analizu je zatvorenost konture te se zbog toga savjetuje korištenje druge metode za provjeru zatvorenosti konture.

## LITERATURA

- [1] T. Keser, G. Kramar, D. Nozica, "Traffic Signs Shape Recognition Based on Contour Descriptor Analysis", In Proceedings of the IEEE International Conference on Smart Systems and Technologies (SST), Osijek, Croatia, 2016.
- [2] M.M Abdulrazzaq, I. FT. Yaseenm SA Noah, M. A. Fadhil, "Multi-Level of Feature Extraction and Classification for X-Ray Medical Image", Indonesian Journal of Electrical Engineering and Computer Science, 2018.
- [3] D. Karthikeyan, G. Balakrishnan, "A comprehensive age estimation on face images using hybrid filter based feature extraction", Special Issue Article - Biomedical Research (2018) Medical Diagnosis and Study of Biomedical Imaging Systems and Applications, Srinivasan Engineering College, India, 2017.
- [4] M. Nixon, A. Aguado, "Feature Extraction & Image Processing for Computer Vision", Academic Press is an imprint of Elsevier, London, 2012.
- [5] G. Stylianou, G. Farin, "Shape Feature Extraction", Hierarchical and Geometrical Methods in Scientific Visualization. Mathematics and Visualization. Springer, Berlin, Heidelberg, 2003.
- [6] V. Kavitha, M. Renuka Devi, "Citrus Fruit Feature Extraction using Colpromatix Color Code Model", Global Journal of Computer Science and Technology: G, Volume 17 Issue 3 Version 1.0, Global Journals Inc. (USA), 2017
- [7] A. Aquino, M. E. Gegúndez-Arias, D. Marin, "Detecting the Optic Disc Boundary in Digital Fundus Images Using Morphological, Edge Detection, and Feature Extraction Techniques", IEEE Transactions on Medical Imaging, Volume: 29, Issue: 11, Nov. 2010
- [8] R. S. Choras, "Image Feature Extraction Techniques and Their Applications for CBIR and Biometrics Systems", International journal of biology and biomedical engineering, 2008.
- [9] L. Prasad, R. Rao, "A Geometric Transform for Shape Feature Extraction", Proc. SPIE 4117, Vision Geometry IX, 23 October 2000
- [10] Ž. Hocenski and T. Keser, "Failure Detection and Isolation in Ceramic Tile Edges Based on Contour Descriptor Analysis", 2007 Mediterranean Conference on Control and Automation, 27-29 July 2007., pp. 1-6
- [11] R. Kothari, „What are the differences between RGB, HSV and CIE-Lab?“, HSV, Quora, 2018., dostupno na: <https://www.quora.com/What-are-the-differences-between-RGB-HSV-and-CIE-Lab>, 20.06.2018.

- [12] U. Sinha, „The Canny Edge Detector“, AI Shack, 2018., dostupno na: <http://aishack.in/tutorials/canny-edge-detector/>, 20.06.2018.
- [13] Š. Bašić, P. Š. Čepo, I. Dodolović, D. Dostal, S. Grbić, M. Gulić, I. Horvatin, S. Louč, I. Sučić, S. Šegvić, „Canneyev detektor rubova Tehnička dokumentacija“, FER, 2009., dostupno na: <http://www.zemris.fer.hr/~ssegvic/project/0809grupa251/canny251.pdf>, 20.06.2018.

## SAŽETAK

### DCT opisnik u analizi 2D oblika

Glavni zadatak diplomskog rada je primijeniti DCT opisnik u analizi 2D oblika. U radu je dana teorijska osnova svih komponenti potrebnih za analizu 2D oblika. Napravljena je analiza na pet oblika generiranih na računalu i dva oblika iz stvarnog svijeta i prikazani su rezultati s vremenima izračuna DCT opisnika i vremenom izvlačenja značajki te rezultati klasifikacije prometnih znakova korištenjem mjere sličnosti.

**Ključne riječi:** DCT opisnik, izvlačenje značajki, analiza 2D oblika, Canny, HSV, klasifikacija oblika, mjera sličnosti

## ABSTRACT

### Title: DCT descriptor in analysis of 2D shapes

The main task in this paper is to apply the DCT descriptor in analysis of 2D Shapes. This paper consists of the theoretical background needed for 2D shape analysis. Analysis were made on five computer generated images and two real life scenes and the results are shown with DCT descriptor times, the time needed for feature extraction and classification of traffic signs using similarity measure.

**Keywords:** DCT descriptor, feature extraction, 2D shapes analysis, Canny, HSV, shape classification, similarity measure

## ŽIVOTOPIS

Gabrijela Kramar rođena je 25.01.1994. godine u Osijeku. Od rođenja živi u Višnjevcu gdje stječe osnovnoškolsko obrazovanje u Osnovnoj školi Višnjevac. U 4. razredu osnovne sudjelovala je u natjecanju iz matematike gdje je osvojila 6. mjesto na državnom natjecanju. 7. i 8. razred osnovne škole sudjelovala je u županijskim natjecanjima iz hrvatskog jezika. Upisala se u 3. gimnaziju Osijek 2009. godine. U srednjoj školi sudjelovala je u županijskim natjecanjima iz kemije i informatike. 2011. preselila se u Topolje gdje i danas još živi. Godine 2013. završava srednju školu i državnu maturu, te upisuje Fakultet elektrotehnike, računarstva i informacijskih tehnologija, preddiplomski studij računarstva, u Osijeku. 2016. godine sudjeluje na konferenciji *Smart Systems and Technologies (SST)* s znanstvenim radom po imenu: *Traffic Signs Shape Recognition Based on Contour Descriptor Analysis* koji je zatim objavljen u zborniku konferencije. Preddiplomski studij računarstva završava 2016. godine i time postiže titulu sveučilišne prvostupnice računarstva. Iste godine upisuje diplomski studij računarstva – smjer programsko inženjerstvo. Godine 2017. pohađa i završava praksu na mjestu softver developera u tvrtki Mono. Godine 2018. upisuje i pohađa SPAN akademiju. Hobi joj je pjevanje u vokalnom ansamblu Brevis s kojim je putovala na brojna svjetska natjecanja i osvajala prva mjesta te dodatne nagrade žirija. Od početka školovanja pa do danas, sve je razrede prošla s odličnim uspjehom.

---

## PRILOZI

MATLAB skripte *main.m*, *CD.m*, *CD\_marking.m*, *CD\_compare*, *CD\_reference* nalaze se na CD-u, zajedno sa slikama za obradu.